

Capítulo 4

Selección y evaluación de modelos de inteligencia artificial para la detección de maleza en cultivos agrícolas

*Karla Vanessa Ayala Cruz*¹

*José de Jesús Valenzuela Hernández*²

*Gilberto Bojórquez Delgado*³

<https://doi.org/10.61728/AE24004534>



¹ Universidad Autónoma Indígena de México, Los Mochis, Sinaloa, México.
Email: ayalacruz05@gmail.com

² Universidad Autónoma Indígena de México, Los Mochis, Sinaloa, México.
Email: josevalenzuela_93@outlook.com

³ Tecnológico Nacional de México Campus Guasave, Guasave, Sinaloa, México.
Email: itsg.gbojorquez@gmail.com

Resumen

Los retos en la agricultura moderna cada vez más complejos y requieren de soluciones más avanzadas en el campo de las tecnologías aplicadas. Uno de los retos más importantes en el campo de la agricultura es la detección y control de malezas, ya que la presencia de ellas presenta pérdidas significativas en el rendimiento proyectado desde la programación del cultivo. El artículo aborda la necesidad de utilizar modelos avanzados de IA para mejorar la gestión de malezas en cultivos de maíz mediante el uso de drones. Se llevó a cabo una revisión sistemática de la literatura para identificar y evaluar los modelos de IA más relevantes: YOLO, Faster R-CNN, ResNet y VGG. El método de análisis fue la revisión sistemática de bibliografía la cual se dividió en tres pasos. Primero, se recopiló bibliografía sobre cada modelo mediante búsquedas exhaustivas en bases de datos académicas como IEEE Xplore, Google Scholar y ScienceDirect. Segundo, se evaluaron los estudios seleccionados según criterios de precisión, velocidad de procesamiento, requerimientos computacionales, robustez y facilidad de implementación. Tercero, se sintetizó la evidencia para determinar el modelo más adecuado. Los resultados indican que YOLO es el modelo más adecuado debido a su capacidad de procesamiento en tiempo real y eficiencia, a pesar de tener una precisión ligeramente inferior comparada con otros modelos. Faster R-CNN ofrece alta precisión y robustez, pero su velocidad es inferior. ResNet se destacó por su alta precisión al igual que VGG, pero sus altos requerimientos computacionales y velocidad limitada los hacen menos práctico.

Introducción

La agricultura, a lo largo de la historia, ha sido el fundamento esencial sobre el cual se erige el desarrollo y la subsistencia de las sociedades humanas. Desde los primeros asentamientos humanos hasta las complejas sociedades modernas, la agricultura ha sido el motor que impulsa

el progreso y el desarrollo. Su evolución a lo largo de milenios ha sido marcada por la innovación, la adaptación y la búsqueda constante de métodos más eficientes y sostenibles.

Desde tiempos inmemoriales, su importancia ha trascendido la mera producción de alimentos, abarcando dimensiones cruciales en términos de economía, sostenibilidad y seguridad alimentaria a escala global. En un contexto donde la población mundial sigue en aumento y los recursos naturales se vuelven cada vez más escasos y el panorama no es muy alentador, el papel de la agricultura en la nutrición y el bienestar humanos adquiere una relevancia sin precedentes. Sin embargo, a pesar de su importancia innegable, la agricultura se enfrenta a una serie de desafíos monumentales en el siglo XXI. La crisis alimentaria global, exacerbada por fenómenos como el cambio climático, conflictos políticos, manejo del agua y pandemias, ha subrayado la urgente necesidad de fortalecer y consolidar el sector agrícola (World Health Organization, 2022). En este escenario, es imperativo adoptar estrategias innovadoras que permitan enfrentar estos desafíos de manera efectiva y sostenible.

Uno de los desafíos más apremiantes en la agricultura moderna es el manejo de malezas, cuya presencia representa una amenaza significativa para la productividad y calidad de los cultivos (Westwood et al., 2018). La detección y control eficaces de estas malezas son fundamentales para maximizar la productividad agrícola, mejorar la eficiencia en el uso de recursos y reducir la dependencia de herbicidas químicos. En este sentido, el desarrollo y aplicación de tecnologías avanzadas, como la inteligencia artificial y la teledetección mediante drones, ofrecen nuevas oportunidades para abordar este desafío de manera más precisa y eficiente (Esposito et al., 2021).

En la agricultura moderna, el uso de tecnologías avanzadas para optimizar la producción y sostenibilidad de los cultivos es cada vez más crucial. Una de estas tecnologías emergentes es el procesamiento de imágenes tomadas desde drones, lo que permite una vigilancia precisa y continua de grandes extensiones de cultivos.

La tecnología de drones y sensores juega un papel crucial en la gestión sostenible de malezas, ofreciendo soluciones innovadoras para el monitoreo y control eficiente de las mismas. La integración de drones

con varios sensores, como hiperespectrales, multiespectrales y RGB, permite una detección y gestión precisa de malas hierbas (Roslim et al., 2021). Estas tecnologías facilitan la gestión de malas hierbas específica para cada sitio, lo que mejora la eficiencia a la vez que beneficia al medioambiente (Esposito et al., 2021). Los drones equipados con sensores pueden proporcionar datos valiosos sobre los niveles de infestación de malas hierbas, permitiendo intervenciones dirigidas y reduciendo el costo general de la producción agrícola (Huang et al., 2018). Conocer las bondades de diferentes modelos de procesamiento de imágenes es fundamental por varias razones. En primer lugar, la elección del modelo adecuado puede influir significativamente en la precisión y eficiencia del análisis de las imágenes, impactando directamente en la capacidad de los agricultores para tomar decisiones informadas y oportunas. Modelos de inteligencia artificial (IA) como las redes neuronales convolucionales (CNN), incluyendo ResNet, VGG, YOLO y Faster R-CNN, ofrecen distintas ventajas y desventajas en términos de precisión, velocidad y requerimientos computacionales.

Analizar estas propiedades permite identificar cuál de estos modelos es el más adecuado para las necesidades específicas del monitoreo de cultivos de maíz. De esta manera, el procesamiento de datos mediante modelos de IA presenta numerosos beneficios. La capacidad de estos modelos para analizar grandes volúmenes de datos de manera rápida y precisa mejora la detección de problemas como la presencia de malezas, plagas y enfermedades en las etapas tempranas. Esto no solo facilita una intervención más rápida y efectiva, sino que también puede conducir a una reducción significativa en el uso de herbicidas y pesticidas, promoviendo prácticas agrícolas más sostenibles. Además, el análisis automatizado reduce la necesidad de inspecciones manuales extensivas, ahorrando tiempo y recursos.

Desde una perspectiva económica, la inversión en tecnologías de procesamiento de imágenes y modelos de IA puede traducirse en un mayor rendimiento de la producción. La capacidad de identificar y abordar problemas de manera temprana y precisa ayuda a maximizar los rendimientos de los cultivos y minimizar las pérdidas. Esto, a su vez, puede mejorar significativamente la rentabilidad para los agricultores, justificando las inversiones iniciales en estas tecnologías avanzadas.

Además, los beneficios del rápido procesamiento y la accesibilidad a modelos más amigables no pueden ser subestimados. Modelos como YOLO, que son conocidos por su velocidad y eficiencia en tiempo real, permiten a los agricultores realizar monitoreos continuos y tomar decisiones inmediatas basadas en datos precisos. La facilidad de implementación y uso de estos modelos también los hace accesibles para una amplia gama de usuarios, incluyendo aquellos con menos experiencia técnica.

En la actualidad, el análisis de modelos de procesamiento de imágenes capturadas por drones en cultivos de maíz es esencial para mejorar la precisión y eficiencia del monitoreo agrícola. La adopción de modelos de IA no solo ofrece beneficios significativos en términos de sostenibilidad y eficiencia, sino que también justifica las inversiones económicas al aumentar el rendimiento y la rentabilidad de la producción agrícola.

Además, el uso de drones junto con sensores terrestres y tecnologías de inteligencia artificial permite la detección de malezas y procesos de toma de decisiones en línea, mejorando la sostenibilidad de las prácticas de control de malezas (Engineering, Technology & Applied Science Research, s. f.). Sin embargo, los avances tecnológicos han facilitado el desarrollo de soluciones basadas en drones para la detección de malezas y la medición de los niveles de infestación de malezas. Además, se han utilizado drones en vuelos poscosecha para medir el crecimiento de las malezas y las asociaciones de rendimiento, lo que proporciona información valiosa para estrategias efectivas de control de malezas (Miller et al., 2022). En este sentido el artículo pretende proporcionar una evaluación detallada de los diferentes modelos, ayudando a identificar las mejores prácticas y tecnologías para optimizar la gestión de cultivos de maíz mediante el uso de drones y procesamiento de imágenes.

El monitoreo constante del control de plagas y malezas en los cultivos de maíz blanco es fundamental para garantizar una producción agrícola eficiente y sostenible. Las malezas, en particular, son una amenaza significativa ya que compiten con los cultivos por recursos esenciales como nutrientes, agua y luz, afectando negativamente los rendimientos. Entre las malezas más comunes que se pueden encontrar en los campos de maíz blanco se incluyen el *Amaranthus palmeri* (amaranto), la *Echinochloa crus-galli* (pata de gallo) y la *Cyperus rotundus* (coquillo). Estas especies

invasoras pueden reducir significativamente la producción del maíz, interfiriendo en su crecimiento y desarrollo al competir agresivamente por los recursos del suelo. El *Amaranthus palmeri*, por ejemplo, es conocido por su rápido crecimiento y alta capacidad de dispersión, lo que lo convierte en una de las malezas más difíciles de controlar. La *Echinochloa crus-galli* puede competir eficazmente con el maíz en las primeras etapas de crecimiento, reduciendo la disponibilidad de luz y nutrientes para el cultivo. La *Cyperus rotundus* es particularmente resistente y puede sobrevivir a condiciones adversas, compitiendo con el maíz durante toda la temporada de crecimiento. La presencia de estas malezas no solo disminuye la cantidad de maíz cosechable, sino que también puede afectar la calidad del grano producido (BASF México, s. f.).

Estar a la vanguardia en tecnología aplicada y métodos de precisión para el control de malezas es crucial para superar estos desafíos. La adopción de tecnologías avanzadas como la inteligencia artificial (IA) y el uso de drones para el monitoreo de campos ha revolucionado la agricultura moderna. Estas tecnologías permiten una detección temprana y precisa de malezas, facilitando intervenciones rápidas y específicas que reducen la competencia de malezas y mejoran los rendimientos del cultivo. Los sistemas de monitoreo continuo basados en IA pueden analizar grandes volúmenes de datos de imágenes, identificando con precisión las áreas afectadas por malezas y plagas. En contraste, las técnicas de evaluación y control de malezas más antiguas, que todavía se utilizan en algunos casos, incluyen métodos manuales de inspección y la aplicación generalizada de herbicidas. Estos métodos son laboriosos y menos precisos, ya que dependen en gran medida de la observación humana, lo que puede llevar a una detección tardía y un control ineficiente. La aplicación indiscriminada de herbicidas no solo es costosa, sino que también puede dañar el medio ambiente y promover la resistencia de las malezas a los productos químicos.

Las acciones más comunes para controlar las malezas en caso de aparecer en el cultivo de maíz incluyen la aplicación de herbicidas selectivos, la rotación de cultivos y el uso de técnicas de cultivo mecánico. La rotación de cultivos ayuda a romper el ciclo de vida de las malezas, reduciendo su prevalencia en los campos. El cultivo mecánico, aunque eficaz en algunos casos, puede ser costoso y menos sostenible a largo

plazo debido al impacto en la estructura del suelo y la posible erosión. El monitoreo constante y el control efectivo de malezas y plagas son esenciales para mantener la productividad de los cultivos de maíz blanco y la adopción de tecnologías avanzadas y métodos de precisión para el control de malezas representa una mejora significativa sobre las técnicas tradicionales, ofreciendo una solución más sostenible y eficiente. Los agricultores que implementan estas tecnologías pueden esperar no solo mejorar sus rendimientos sino también reducir los costos operativos y minimizar el impacto ambiental, contribuyendo así a una agricultura más sostenible y rentable.

De acuerdo con lo anterior se considera importante la implementación de modelos de procesamiento de datos más amigables y con mayor velocidad de procesamiento ya que estas acciones traen consigo numerosos beneficios en el campo de la agronomía. En primer lugar, estos modelos permiten una toma de decisiones más rápida y precisa, lo que es crucial en un entorno donde las condiciones de los cultivos pueden cambiar rápidamente y las intervenciones deben ser oportunas. En este sentido es fundamental analizar diferentes modelos de procesamiento para seleccionar el más adecuado, ya que cada cultivo y cada situación específica puede requerir enfoques distintos. Por ejemplo, algunos modelos pueden ser más efectivos para detectar enfermedades en etapas tempranas, mientras que otros pueden ser más adecuados para la gestión del riego o la estimación de la biomasa.

Trabajos relacionados

En el artículo “Uso de sensores remotos y un sistema aéreo no tripulado para el manejo de malezas en cultivos agrícolas: Una revisión”, se señala que las malezas reducen el rendimiento de los cultivos al competir por recursos esenciales y que la integración de drones, IA y sensores (hiperespectrales, multispectrales y RGB) mejora significativamente el manejo de malezas. En este sentido, la detección remota es una herramienta multidisciplinaria que aborda desafíos futuros como la seguridad alimentaria y la resistencia a herbicidas. En esta investigación se destaca el uso de vehículos aéreos no tripulados (UAV) y técnicas de detección

remota en la gestión de malezas, demostrando su efectividad en superar desafíos agrícolas futuros (Roslim et al., 2021).

Para llevar a cabo la investigación se realizaron experimentos en campos de frijoles y espinacas utilizando imágenes capturadas por un dron DJI Phantom 3 Pro. El desempeño del método no supervisado propuesto se comparó con el etiquetado supervisado, mostrando resultados similares con pequeñas diferencias de precisión. El estudio encontró que el método no supervisado es efectivo, especialmente con el aumento de datos, y destacó la robustez de modelos de aprendizaje profundo como ResNet18. El documento concluye que el método completamente automático propuesto utilizando CNN con etiquetado de datos no supervisado es efectivo para la detección de malas hierbas en imágenes de UAV. El método ofrece flexibilidad y adaptabilidad para diferentes conjuntos de datos y podría ser valioso para la detección en línea de malas hierbas en la agricultura de precisión. Los trabajos futuros explorarán el uso de imágenes multiespectrales para mejorar la segmentación y la precisión de la clasificación.

Así mismo en el artículo “Detección de malezas basada en aprendizaje profundo mediante imágenes de UAV: Un estudio comparativo”, se concluye que la segmentación semántica es crucial en la agricultura de precisión para la detección de malezas. Aquí se analizaron varios modelos de segmentación basados en IA para la detección de malezas utilizando imágenes RGB de UAV y se encontró que UNet con EfficientNetB0 es el modelo de mejor rendimiento, sugiriendo que puede ser utilizado por agricultores para detectar malezas con mayor precisión, mejorando el rendimiento de los cultivos (Shahi et al., 2023). Entre los hallazgos se determina que la metodología propuesta muestra un rendimiento cercano al etiquetado supervisado en términos de precisión, con diferencias de AUC del 1.5 % en el campo de espinacas y del 6 % en el campo de frijoles. También concluye que el etiquetado no supervisado reduce significativamente la necesidad de intervención manual, lo que puede resultar en ahorros considerables en tiempo y costos. Por otra parte, concibe el método como flexible y con la característica de adaptarse fácilmente a nuevos conjuntos de datos, lo cual es esencial para diferentes condiciones agrícolas y tipos de cultivos. Así mismo, planea usar imágenes

multiespectrales para mejorar aún más la segmentación del fondo y la distinción entre plantas, incluso en condiciones de similitud espectral y forma de las hojas.

En el artículo “Tecnología de sensores y drones para el manejo sostenible de malezas: Una revisión”, se analiza el manejo integrado de malezas utilizando drones que permite un control específico y eficiente de malezas en sitios particulares. Este enfoque combina la adquisición de imágenes mediante drones y su procesamiento con técnicas de aprendizaje automático, entrenando algoritmos para gestionar la eliminación de malezas de manera autónoma. La revisión destaca la necesidad de comprender la dinámica de las malezas y su competencia con los cultivos para implementar este enfoque en contextos agrícolas reales (Esposito et al., 2021). La investigación concluye que el uso de UAV y las técnicas de aprendizaje automático permite la identificación precisa de parches de malezas en campos cultivados, mejorando la sostenibilidad del manejo de malezas. La integración de tecnologías emergentes en este campo mejorará significativamente la sostenibilidad del control de malezas, proporcionando una visión confiable del nivel y tipo de infestación, y permitiendo la gestión mediante robots autónomos. Sin embargo, se necesita una comprensión completa de la dinámica de las poblaciones de malezas y su competencia con los cultivos para implementar esta tecnología en contextos agrícolas reales.

En otro artículo llamado “Una revisión de las aplicaciones basadas en UAV para la agricultura de precisión”, se determina que las tecnologías emergentes como el Internet de las cosas (IoT) y UAV tienen un potencial significativo en la agricultura inteligente, permitiendo la toma de decisiones rápidas y precisas. Este artículo revisa las aplicaciones de UAV en la agricultura de precisión, discutiendo los métodos de adquisición y procesamiento de datos, y destacando los beneficios y desventajas de cada tecnología. También se aborda la falta de un flujo de trabajo estandarizado para el uso de UAV en estas aplicaciones (Tsouros et al., 2019).

Por otra parte, en la investigación “Avances de vehículos aéreos no tripulados y tecnologías de aprendizaje profundo para el manejo de malezas en tierras agrícolas”, se afirma que la tecnología UAV y las redes neuronales convolucionales (CNN) han mejorado significativamente la

detección de malezas, plagas y otros factores abióticos que afectan el rendimiento de los cultivos. Este estudio presenta los avances en plataformas UAV y CNN, y su aplicación en la agricultura, destacando las limitaciones actuales y las tendencias futuras en el manejo de malezas (Zhang et al., 2024).

Al concluir la investigación se determinó, que las imágenes capturadas por drones a menudo se ven afectadas por factores como la iluminación, sombras y oclusión, lo que presenta dificultades para la identificación precisa de malezas, por lo que la precisión y confiabilidad de la identificación de malezas como elemento clave de la investigación puede ser errónea (Advancements in UAV Technology).

El documento también concluye que la investigación y aplicación de drones en la gestión de malezas han mostrado resultados positivos, pero aún enfrentan desafíos. La necesidad de mejorar la colaboración entre drones y equipos terrestres, así como la generalización y robustez de los modelos de aprendizaje profundo, es fundamental. Se enfatiza la importancia de aplicar esta tecnología en la producción agrícola real para soluciones más eficientes e inteligentes y que la investigación futura debe centrarse en mejorar la precisión de la identificación de malezas, la colaboración entre drones y equipos terrestres, y la aplicación práctica en la producción agrícola. Además, es necesario explorar formas de aplicar estas tecnologías a gran escala en la producción agrícola (Advancements in UAV Technology).

Así mismo en el documento “Inteligencia artificial en tareas de reconocimiento de malezas”, se determina que el uso de redes neuronales para el reconocimiento de malezas ha avanzado significativamente en la última década. Este manuscrito presenta un análisis de los resultados del uso de diversos algoritmos de redes neuronales para la clasificación y seguimiento de malezas, recomendando estándares que pueden mejorar la calidad de la investigación en este campo (Ildar, 2020).

La mayoría de los estudios revisados utilizan técnicas de procesamiento de imágenes como filtros de color, suavizado de imágenes, y transformaciones morfológicas para mejorar la calidad de las imágenes antes de ser procesadas por las redes neuronales. En este sentido, se determina que el procesamiento previo de las imágenes es crucial para mejorar la

calidad y precisión del reconocimiento de malezas. Se utilizan diversas técnicas de la biblioteca OpenCV, como filtros Gaussianos y Laplacianos, transformaciones afines y de perspectiva, y detección de bordes.

De igual manera, se concluye que las redes neuronales convolucionales (CNN) son ampliamente utilizadas para la extracción de características y la clasificación de objetos en imágenes agrícolas. Métodos como YOLO, Faster R-CNN y RetinaNet han mostrado buenos resultados en la detección de malezas, aunque enfrentan desafíos como la necesidad de alta potencia de cómputo y la limitación de recursos en dispositivos como Raspberry Pi. Los principales desafíos incluyen la complejidad de reconocer malezas en diferentes condiciones ambientales y la velocidad de reconocimiento.

En el documento “Métodos de aprendizaje automático para agricultura de precisión con imágenes de UAV: Una revisión”, se afirma que la teledetección basada en UAV ha ganado atención en la agricultura de precisión debido a los sensores avanzados y métodos de análisis de datos. Este artículo revisa y compara diversos métodos de aprendizaje automático y aprendizaje profundo para aplicaciones agrícolas, mostrando cómo la fusión de múltiples características puede mejorar el rendimiento de los modelos. También se discuten las tendencias recientes y los desafíos en este campo (Shahi et al., 2022).

Marco teórico

Inteligencia artificial (IA)

La inteligencia artificial (IA) ha evolucionado significativamente en las últimas décadas, convirtiéndose en una herramienta fundamental en diversos campos, incluida la agricultura de precisión. En lo que respecta al propio término de inteligencia artificial, el Ministerio de Ciencia, Innovación y Universidades (2019) lo define como “la Ciencia e Ingeniería que permite diseñar y programar máquinas capaces de llevar a cabo tareas que requieren inteligencia para ser realizadas” (p. 13). Sin embargo, para profundizar y poder comprender dicha tecnología, haremos referencia a los cuatro tipos de IA definidos por Arend Hintze (<http://hdl.handle.net/10654/39998>).

En primer lugar, se encuentran las llamadas máquinas reactivas. Son las más básicas y no pueden formar recuerdos ni utilizar experiencias pasadas para tomar decisiones. El segundo tipo (memoria limitada), a diferencia del primero, es capaz de adquirir información de experiencias pasadas, aunque su memoria es transitoria y no se puede utilizar para futuras experiencias. En tercer lugar, encontramos las máquinas con una “Teoría de la mente”, las cuales son capaces de formar representaciones del mundo y sobre otros agentes o entidades con los que interactúa. El cuarto y último tipo de IA es la autoconciencia. Se trata de una extensión de la “Teoría de la mente” y se basa en construir sistemas que sean capaces de crear representaciones sobre sí mismas.

Agricultura de precisión

Adamides (2020), menciona que “La agricultura de precisión es una metodología de gestión agrícola que utiliza tecnologías avanzadas para medir y analizar datos sobre las variaciones dentro de los campos, permitiendo a los agricultores optimizar el uso de insumos y mejorar la eficiencia y sostenibilidad de la producción”.

Rodrigues (2021) señala que “La agricultura de precisión es un enfoque de gestión agrícola que integra tecnologías de información y comunicación, incluyendo IoT y análisis de big data, para monitorear y gestionar los cultivos con alta precisión, mejorando la productividad y reduciendo el impacto ambiental”.

García y Jiménez (2021) concluyen que “La agricultura de precisión se refiere a la gestión agrícola basada en la observación y medición de las condiciones del suelo y el cultivo, y la aplicación de tratamientos específicos en tiempo real para mejorar la productividad y sostenibilidad de los cultivos”.

Según Rodríguez (2022), la Sociedad Internacional de Agricultura de Precisión define la agricultura de precisión como “una estrategia de gestión que recopila, procesa y analiza datos temporales, espaciales e individuales y los combina con otra información para apoyar decisiones de gestión según la variabilidad estimada, mejorando la eficiencia en el uso de recursos, productividad, calidad, rentabilidad y sostenibilidad de la producción agrícola”.

Malezas

Adamides (2020), sostiene que “Las malezas son plantas no deseadas que compiten con los cultivos por recursos esenciales y pueden reducir significativamente la cantidad y calidad de la producción agrícola. Además, pueden actuar como hospederos alternativos para plagas y patógenos, lo que agrava aún más su impacto negativo”. Además, Sulaiman (2021), sostiene que las malezas son plantas no deseadas que compiten con los cultivos por recursos esenciales como agua, nutrientes, luz y espacio. Esta competencia puede resultar en una reducción significativa del rendimiento de los cultivos, afectando tanto la cantidad como la calidad de la producción. En cultivos de maíz, malezas como *Amaranthus palmeri* (amaranto), *Echinochloa crus-galli* (pata de gallo) y *Cyperus rotundus* (coquillo) son especialmente problemáticas debido a su rápida propagación y resistencia a los herbicidas

Tecnologías de monitoreo y detección

Mishra (2022) define que “El uso de vehículos aéreos no tripulados (UAV) equipados con sensores avanzados (hiperespectrales, multiespectrales y RGB) ha revolucionado el monitoreo de cultivos. Estos drones pueden capturar imágenes de alta resolución que permiten la detección precisa y temprana de malezas. Las imágenes capturadas son procesadas mediante técnicas de inteligencia artificial (IA) para identificar y localizar malezas de manera eficiente.

Ayoub Shaikh (2023) menciona que “Las tecnologías de monitoreo y detección en la agricultura emplean una combinación de sensores remotos y técnicas de procesamiento de imágenes para identificar y gestionar problemas en los cultivos, como enfermedades y plagas. Estos sistemas pueden incluir cámaras de alta resolución, sensores de temperatura y humedad, y algoritmos de inteligencia artificial para analizar los datos recogidos y proporcionar recomendaciones precisas para la gestión agrícola”.

Modelos de inteligencia artificial

García y Jiménez (2021) sostienen que “Los modelos de IA para la agricultura de precisión incluyen algoritmos de aprendizaje automático (ML) y aprendizaje profundo (DL), que se utilizan para analizar datos de sensores de suelo, humedad y nutrientes. Estos modelos permiten tomar decisiones informadas para mejorar la productividad y sostenibilidad de la agricultura”.

Akbar (2023): “Los modelos de IA en la agricultura se utilizan para la detección y clasificación de enfermedades de los cultivos. Los modelos basados en aprendizaje automático (ML) y aprendizaje profundo (DL) permiten identificar y clasificar enfermedades mediante el análisis de imágenes de hojas u otras características de las plantas. Esto ayuda a los agricultores a manejar y controlar las enfermedades de manera más efectiva”. En este mismo sentido, Kaur y Sharma (2023) expresan que “Los modelos de IA en la detección de enfermedades de plantas incluyen algoritmos de aprendizaje automático (ML) como el clasificador c4.5 y las máquinas de vectores de soporte lineal (SVM), así como modelos de aprendizaje profundo (DL) como las redes neuronales convolucionales (CNN) y las redes de creencias profundas (DBN). Estos modelos son capaces de aprender características a partir de imágenes y detectar síntomas sutiles de enfermedades que los métodos tradicionales de procesamiento de imágenes pueden no identificar”.

Los modelos de IA, especialmente las redes neuronales convolucionales (CNN), han demostrado ser extremadamente efectivos para el procesamiento y análisis de imágenes agrícolas. Modelos como ResNet, VGG, YOLO y Faster R-CNN se utilizan ampliamente para tareas de detección de objetos y clasificación de imágenes.

- **ResNet (Residual Networks):** Conocido por su capacidad para manejar redes muy profundas, lo que mejora la precisión en la detección.
- **VGG (Visual Geometry Group):** Utiliza capas convolucionales pequeñas que ofrecen una arquitectura simple y efectiva.
- **YOLO (You Only Look Once):** Destaca por su velocidad y capacidad de procesamiento en tiempo real.

- **Faster R-CNN:** Combina una red de propuestas de regiones (RPN) con una CNN para lograr una alta precisión en la detección de múltiples objetos.

Comparación de modelos de IA

Un estudio comparativo de diversos modelos de segmentación semántica basados en IA para la detección de malezas utilizando imágenes RGB de UAV identificó que UNet combinado con EfficientNetB0 es el modelo de mejor rendimiento. Este modelo demostró una alta precisión, recall y puntuación F1, lo que lo hace ideal para aplicaciones agrícolas (Osorio et al., 2020).

Beneficios del uso de IA en la agricultura

El procesamiento de datos mediante modelos de IA ofrece numerosos beneficios, incluyendo:

- **Precisión en la Detección:** Mejora la identificación temprana y precisa de malezas, permitiendo intervenciones rápidas y específicas (Haq et al., 2023).
- **Mejora en los Rendimientos:** Al gestionar eficazmente las malezas, se optimiza el crecimiento del cultivo, aumentando la producción y calidad de la cosecha (Dasgupta et al., 2023).
- **Eficiencia Operativa:** Reduce la necesidad de inspecciones manuales extensivas y permite el uso selectivo de herbicidas, disminuyendo costos y el impacto ambiental (Prostko et al., 2024).

Metodología

Para garantizar la selección y aplicación de los modelos de IA más efectivos en el procesamiento de imágenes tomadas por drones, es esencial realizar una revisión sistemática de la literatura, ya que permite recopilar, evaluar y sintetizar de manera rigurosa la evidencia disponible sobre los diferentes modelos de IA utilizados en este contexto. Este enfoque no solo asegura una comprensión exhaustiva de las tecnologías actuales, sino que también identifica las mejores prácticas y las áreas que requieren más

investigación. La metodología estructurada y transparente de la revisión sistemática minimiza los sesgos y proporciona una base sólida para la toma de decisiones informadas en la implementación de tecnologías de IA en la agricultura.

Dada la variabilidad en las características y el rendimiento de los diferentes modelos de IA, como las redes neuronales convolucionales (CNN), las máquinas de vectores de soporte (SVM) y los algoritmos de aprendizaje profundo (DL), la revisión sistemática ofrece una evaluación crítica y comparativa que es fundamental para optimizar su uso en la detección de malezas. Además, la integración de imágenes de alta resolución capturadas por drones añade una capa de complejidad y oportunidad que puede ser mejor comprendida y explotada mediante una revisión exhaustiva de la literatura existente.

Revisión sistemática de literatura sobre modelos de IA para la detección de malezas en cultivos de maíz blanco

Paso 1: Recopilación de bibliografía sobre modelos de IA

El primer paso de la revisión sistemática consistió en la recopilación exhaustiva de bibliografía relacionada con los modelos de inteligencia artificial más relevantes utilizados en la detección de malezas en cultivos agrícolas. Los modelos específicos considerados fueron ResNet (Residual Networks), VGG (Visual Geometry Group), YOLO (You Only Look Once) y Faster R-CNN. Para llevar a cabo esta recopilación, se realizaron búsquedas en bases de datos académicas y científicas como IEEE Xplore, Google Scholar, ScienceDirect y MDPI, utilizando palabras clave como “ResNet weed detection”, “VGG crop analysis”, “YOLO agriculture”, y “Faster R-CNN plant diseases”.

Se identificaron y seleccionaron estudios relevantes publicados en los últimos cinco años (2019-2024) para asegurar que la información estuviera actualizada. Los estudios seleccionados incluyeron investigaciones empíricas, revisiones de literatura y artículos de conferencia que discutieran el desarrollo, implementación y evaluación de estos modelos de IA en el contexto de la agricultura de precisión.

Paso 2: Evaluación de la Información

Una vez recopilada la bibliografía, se procedió a la evaluación crítica de los estudios seleccionados. Los criterios de análisis utilizados para revisar y comparar los modelos de IA fueron los siguientes:

1. **Precisión de detección:** La capacidad del modelo para identificar correctamente las malezas en imágenes de cultivos, medida a través de métricas como la precisión, el recall y la puntuación F1.
2. **Velocidad de procesamiento:** El tiempo requerido por el modelo para procesar una imagen y generar resultados, evaluando su aplicabilidad en tiempo real.
3. **Requerimientos computacionales:** La cantidad de recursos computacionales necesarios para entrenar y ejecutar el modelo, incluyendo el uso de GPU y memoria.
4. **Robustez y generalización:** La capacidad del modelo para mantener un buen rendimiento en diferentes condiciones y escenarios de cultivo, evaluando su adaptabilidad y robustez frente a variaciones en los datos de entrada.
5. **Facilidad de implementación:** La simplicidad del proceso de implementación del modelo, incluyendo la disponibilidad de código abierto, la documentación y la facilidad de integración con otras tecnologías agrícolas.

Selección de modelos de IA

Tabla 1
Redes neuronales convolucionales (CNN).

Referencia	Nombre del artículo	Modelo usado	Cultivo	Características de las fotos
<p>https://iieta.org/journals/ria/paper/10.18280/ria.360102</p> <p>Este estudio de detección de malezas en el cultivo de guisantes, se utilizó el modelo Faster R-CNN con ResNet-50. La investigación mostró que esta combinación era capaz de identificar y localizar cultivos y malezas con alta precisión. La utilización de Google Colab y TensorFlow permitió un entrenamiento eficiente, y el modelo demostró una precisión promedio (mAP) alta, con resultados que se estabilizaron alrededor de un valor de pérdida inferior a 0.05, indicando un buen aprendizaje.</p>	<p>Weed Detection in Pea Cultivation with the Faster RCNN ResNet 50 Convolutional Neural Network</p>	<p>Para esta investigación se adoptó el modelo Faster R-CNN ResNet 50 para detectar el cultivo, combina las funcionalidades de dos modelos. (Faster R-CNN y ResNet 50)</p>	<p>Guisantes</p>	<p>Los datos de entrenamiento contienen 1156 imágenes, y para enriquecer el DataSet se procedió a aumentar los datos, utilizando métodos de procesamiento de imágenes con la biblioteca Python OpenCv. A partir de una sola imagen se generan 8 imágenes diferentes, rotación de 180°, aumentos y disminuciones de brillo, reflejo horizontal, mejora de contraste, ruido gaussiano y equalización de histograma. Con estos métodos se obtuvieron 9248 imágenes.</p>

<p>https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2023.1205151/full</p> <p>Este estudio propuso un modelo basado en VGG16 mejorado para identificar malezas en campos de maíz. Utilizando técnicas de aprendizaje por transferencia, el modelo alcanzó una precisión del 91.08 % en el conjunto de validación y del 80 % en campos reales. Este enfoque demuestra la efectividad de VGG16 en entornos agrícolas complejos</p>	<p>A new model based on improved VGG16 for corn weed identification</p>	<p>SE-VGG16</p>	<p>Plántula de maíz</p>	<p>Se recopilaron imágenes de plántulas de maíz y malezas de Gitee (https://gitee.com/Monster7/weed-dataset/tree/master/) a través de Internet, y el conjunto de datos sobre malezas del maíz se tomó de campos de plántulas de maíz en su entorno natural. Se utilizó una cámara Canon PowerShot SX600 HS, con la cámara apuntando verticalmente hacia el suelo para reducir el efecto de los reflejos de la luz solar. Después de la identificación de expertos y la selección manual, se obtuvo un total de 6.000 imágenes, incluidas imágenes de una plántula de maíz y cuatro especies de malezas de maíz, con las categorías de malezas Bluegrass, Chenopodium album, Cirsium setosum y Sedge.</p>
--	---	-----------------	-------------------------	---

Fuente: creación propia.

Tabla 2*Modelos de detección de objetos.*

Referencia	Nombre del Artículo	Modelo Usado	Cultivo	Características de las fotos
<p>https://www.frontiersin.org/journals/plant-science/articles/10.3389/fpls.2022.1091655/full</p> <p>YOLO (You Only Look Once) es una familia de modelos de detección de objetos que se caracteriza por su alta velocidad y precisión en la identificación de objetos en tiempo real. Estos modelos dividen la imagen de entrada en una cuadrícula y predicen las cajas delimitadoras y las probabilidades de clase para cada cuadrícula. Esta arquitectura ha sido ampliamente utilizada en la agricultura para la detección de malezas debido a su capacidad de procesar imágenes de alta resolución rápidamente.</p>	<p>TIA-YOLOv5: An improved YOLOv5 network for real-time detection of crop and weed in the field</p>	<p>Se desarrolló una red YOLOv5 mejorada denominada TIA-YOLOv5TIA-YOLOv5</p>	<p>Remolacha azucarera</p>	<p>El número total de imágenes alcanzó 5536. El conjunto de datos mejorado contiene 4100 imágenes originales y 1436 imágenes sintéticas, se dividió en un conjunto de entrenamiento, un conjunto de validación y un conjunto de prueba.</p>

<p>https://www.mdpi.com/2073-4395/12/12/2953 Faster R-CNN es un modelo de detección de objetos de dos etapas que utiliza una Red de Propuestas de Regiones (RPN) para generar propuestas de objetos y luego clasificar estas regiones usando una red CNN. Esta arquitectura ha demostrado ser altamente efectiva para la detección precisa de malezas en diversos entornos agrícolas debido a su capacidad para manejar múltiples escalas y tipos de objetos.</p>	<p>Intelligent Weed Management Based on Object Detection Neural Networks in Tomato Crops</p>	<p>El procedimiento se basa en redes neuronales de detección de objetos llamadas RetinaNet. Además, también se evaluaron dos modelos actuales de detección de objetos convencionales, a saber, YOLOv7 y FasterRCNN</p>	<p>Tomate</p>	<p>Todas las imágenes fueron recolectadas en campos comerciales bajo condiciones reales de iluminación no controlada durante varios días en diferentes momentos, con el fin de capturar diferentes fondos del suelo, sombras y condiciones de iluminación. Se capturaron un total de 1713 imágenes.</p>
---	--	--	---------------	---

Fuente: creación propia.

Tabla 3

Resultados de análisis de los modelos de IA

Modelo	Descripción	Ventajas	Desventajas	Aplicaciones relevantes
ResNet (Residual Networks)	Red neuronal profunda con múltiples capas residuales para evitar problemas de gradiente desvanecido.	Alta precisión Evita el problema de gradiente desvanecido	Requiere gran capacidad computacional Tiempo de entrenamiento largo	Clasificación de imágenes, detección de objetos complejos donde la precisión es crítica.

Modelo	Descripción	Ventajas	Desventajas	Aplicaciones relevantes
VGG (Visual Geometry Group)	Red profunda con arquitectura simple y capas convolucionales de tamaño fijo.	Arquitectura simple Buen rendimiento en DataSets grandes	Muy intensivo en recursos Tiempo de entrenamiento largo	Adecuada para tareas de clasificación de imágenes y donde la simplicidad del modelo es preferida.
YOLO (You Only Look Once)	Algoritmo de detección de objetos en tiempo real	Detección en tiempo real Alta velocidad	Menor precisión en comparación con otros modelos Requiere ajustes finos	Ideal para aplicaciones en tiempo real debido a su rapidez, como en sistemas de vigilancia y vehículos autónomos.
Faster R-CNN	Red de Convolución con región propuesta rápida	Alta precisión Manejo eficiente de detección de múltiples objetos	Lento en comparación con YOLO Complejo de implementar	Utilizado en tareas donde se requiere alta precisión en la detección y clasificación de múltiples objetos en imágenes de alta resolución

Fuente: creación propia.

Paso 3: Síntesis de la evidencia

La síntesis de la evidencia se realizó mediante un análisis comparativo de los resultados obtenidos de los estudios evaluados. Los principales hallazgos fueron los siguientes:

- **ResNet (Residual Networks):** Se destacó por su alta precisión en la detección de malezas, gracias a su capacidad para manejar redes

profundas y complejas. Sin embargo, su velocidad de procesamiento y altos requerimientos computacionales limitan su aplicabilidad en escenarios de tiempo real.

- **VGG (Visual Geometry Group):** Ofreció una arquitectura más simple y una precisión competitiva, pero al igual que ResNet, sus altos requerimientos computacionales y menor velocidad de procesamiento presentaron desafíos para su implementación en campo.
- **YOLO (You Only Look Once):** Se destacó por su rapidez y capacidad de procesamiento en tiempo real, siendo especialmente adecuado para aplicaciones que requieren monitoreo continuo y decisiones rápidas. Sin embargo, su precisión fue ligeramente inferior en comparación con ResNet y VGG en algunas condiciones.
- **Faster R-CNN:** Combinó una alta precisión con una robustez significativa frente a variaciones en los datos de entrada. Aunque su velocidad de procesamiento fue mejor que la de ResNet y VGG, todavía no alcanzó la eficiencia de YOLO.

Discusión y debate teórico

La revisión sistemática de literatura sobre modelos de inteligencia artificial (IA) para la detección de malezas en cultivos de maíz blanco reveló que los diferentes modelos tienen características únicas que los hacen más o menos adecuados para esta tarea específica. Aquí se presentan los hallazgos de manera resumida y ordenados del modelo más adecuado al menos adecuado.

YOLO (You Only Look Once)

El modelo YOLO es el más adecuado para la detección de malezas debido a su capacidad de procesamiento en tiempo real. Redmon et al. (2016) demostraron que YOLO es extremadamente rápido, permitiendo el monitoreo continuo y respuestas rápidas en el campo, lo cual es crucial para aplicaciones prácticas en la agricultura de precisión. Aunque su precisión es ligeramente inferior a la de algunos modelos más complejos, su eficiencia y velocidad lo hacen ideal para su implementación en drones y sistemas de monitoreo agrícola.

Faster R-CNN

Faster R-CNN combina alta precisión con robustez, lo que lo hace muy efectivo para la detección de malezas en diversas condiciones. Ren et al. (2015) destacaron que este modelo genera propuestas de objetos de alta calidad y es muy preciso. Sin embargo, su velocidad de procesamiento es menor que la de YOLO, lo que puede limitar su uso en aplicaciones que requieren análisis en tiempo real. Aun así, es una opción sólida cuando la precisión es prioritaria y la velocidad no es crítica.

ResNet (Residual Networks)

ResNet es conocido por su alta precisión debido a su capacidad para manejar redes profundas y complejas, como señalaron He et al. (2016). No obstante, sus altos requerimientos computacionales y su menor velocidad de procesamiento lo hacen menos práctico para aplicaciones en campo que requieren decisiones rápidas. ResNet es más adecuado para situaciones donde la precisión extrema es necesaria y hay disponibilidad de recursos computacionales suficientes.

VGG (Visual Geometry Group)

El modelo VGG ofrece una arquitectura simple y competitiva en términos de precisión. Simonyan y Zisserman (2014) mostraron que VGG es fácil de entrenar y ajustar. Sin embargo, su eficiencia computacional y velocidad de procesamiento son menores, lo que limita su aplicabilidad en escenarios de monitoreo en tiempo real en la agricultura.

Conclusión

En conclusión, la revisión sistemática de la literatura sugiere que YOLO es el modelo más adecuado para la detección de malezas en cultivos de maíz blanco debido a su velocidad y eficiencia en tiempo real. Faster R-CNN también es altamente efectivo, especialmente en términos de precisión y robustez, pero su velocidad inferior lo hace menos práctico para

aplicaciones en tiempo real. ResNet y VGG, aunque precisos, presentan limitaciones significativas en términos de requerimientos computacionales y velocidad de procesamiento, lo que los hace menos adecuados para su uso en el campo. Estos hallazgos proporcionan una base sólida para la implementación de tecnologías de IA en la agricultura de precisión, mejorando la gestión de cultivos y promoviendo prácticas agrícolas más sostenibles.

Referencias

- Adamides, (2020). Smart farming for improving agricultural management. ScienceDirect. <https://www.sciencedirect.com>
- AI Index Report. (2024). Artificial Intelligence Index. Stanford AI Index.
- Akbar, M. (2023). A comparative study of AI models for plant disease detection. *Journal of Big Data*. Recuperado de *Journal of Big Data*
- Ayoub Shaikh (2023). Revolutionizing agriculture with artificial intelligence: plant disease detection methods, applications, and their limitations. *Frontiers in Plant Science*.
- Dasgupta, P. (2023). An image processing approach for weed detection using deep learning. Springer
- Food and Agriculture Organization (FAO). (2024). Integrated Weed Management. FAO Integrated Weed Management
- Garcia, L., & Jimenez, J. M. (2021). A Wireless Sensor Network Deployment for Soil Moisture Monitoring in Precision Agriculture. *Sensors*. <https://www.mdpi.com>
- GeoPard Agriculture (2023). Monitoring and Detection Technologies in Agriculture. GeoPard Agriculture
- GeoPard Agriculture (2023). Weed Control in Agriculture. GeoPard Agriculture
- Gonzalez-Andujar, J. L. (2023). Integrated Weed Management: A Shift towards More Sustainable and Holistic Practices. *MDPI Agronomy*. MDPI Agronomy
- Haq, S. I. U. (2023). Weed detection in wheat crops using image analysis and AI. *Applied Sciences*, 13(15), 8840.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.

- Hong (2022). Boosting precision crop protection towards agriculture 5.0 via machine learning and emerging technologies: A contextual review. *Frontiers in Plant Science*. <https://www.frontiersin.org>
- IEEE Xplore (2022). *Advances in Monitoring and Detection Technologies for Agriculture*. IEEE Xplore
- IEEE (2021). *Machine Learning Applications for Precision Agriculture*. IEEE Xplore. <https://ieeexplore.ieee.org>
- Kaur, H., & Sharma, R. (2023). Plant disease detection using AI technologies. *Frontiers in Plant Science*. *Frontiers in Plant Science*.
- Mishra, P. (2022). Advances in UAV and sensor technology for precision agriculture. *Remote Sensing*, 14(3), 503.
- Mulla, D. J. (2013). Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems Engineering*, 114(4), 358-371.
- Osorio, L. (2020). Deep learning based image processing in lettuce crops for weed detection. *ScienceDirect*.
- Oxford Bibliographies. (2022). *Theory and Practice of Biological Control*. Oxford Bibliographies
- Prostko, E. (2024). Evaluation of inference performance of deep learning models for real-time weed detection in an embedded computer. *Sensors*, 24(2), 514.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*.
- Rodrigues, G. C. (2021). *Precision Agriculture: Strategies and Technology Adoption*. *Agriculture 4.0 Review*. <https://www.agriculture.com>
- Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv preprint arXiv:1409.1556*.
- Sulaiman, M. N. (2021). Weed detection in maize fields using UAV imagery and deep learning. *Computers and Electronics in Agriculture*, 182, 105998.

- Engineering, Technology & Applied Science Research. (s. f.). Applications of Artificial Intelligence in Agriculture: A Review. Consultado el 4 de marzo de 2024 en <https://etasr.com/index.php/ETASR/article/view/2756/pdf>
- Esposito, M., Crimaldi, M., Cirillo, V., Sarghini, F., & Maggio, A. (2021). Drone and sensor technology for sustainable weed management: a review. *Chemical and Biological Technologies in Agriculture*, 8(1), 1-11. <https://doi.org/10.1186/S40538-021-00217-8/TABLES/4>
- Huang, Y., Reddy, K. N., Fletcher, R. S., & Pennington, D. (2018). UAV Low-Altitude Remote Sensing for Precision Weed Management. *Weed Technology*, 32(1), 2-6. <https://doi.org/10.1017/WET.2017.89>
- Ildar, R. (2020). Artificial Intelligence in Weed Recognition Tasks. *Asian Journal of Applied Science and Technology*, 04(02), 70-81. <https://doi.org/10.38177/ajast.2020.4210>
- Miller, J. O., Shober, A. L., & VanGessel, M. J. (2022). Post-harvest drone flights to measure weed growth and yield associations. *Agricultural and Environmental Letters*, 7(1). <https://doi.org/10.1002/AEL2.20081>
- BASF México. (s. f.). Plagas y enfermedades en el cultivo del maíz: conoce las principales. <https://agriculture.basf.com/mx/es/contenidos-de-agricultura/plagas-enfermedades-maiz.html>
- Roslim, M. H. M., Juraimi, A. S., Che'ya, N. N., Sulaiman, N., Manaf, M. N. H. A., Ramli, Z., & Motmainna, M. (2021). Using Remote Sensing and an Unmanned Aerial System for Weed Management in Agricultural Crops: A Review. *Agronomy*, 11(9), 1809. <https://doi.org/10.3390/AGRONOMY11091809>
- Shahi, T. B., Dahal, S., Sitaula, C., Neupane, A., & Guo, W. (2023). Deep Learning-Based Weed Detection Using UAV Images: A Comparative Study. *Drones*, 7(10), 624. <https://doi.org/10.3390/DRONES7100624>
- Shahi, T. B., Xu, C.-Y., Neupane, A., Guo, W., Shahi, T. B., Xu, C.-Y., Neupane, A., & Guo, W. (2022). Machine learning methods for precision agriculture with UAV imagery: a review. *Electronic Research Archive*, 30(12), 4277-4317. <https://doi.org/10.3934/ERA.2022218>
- Tsouros, D. C., Bibi, S., & Sarigiannidis, P. G. (2019). A Review on UAV-Based Applications for Precision Agriculture. *Information* 2019, 10(11), 349. <https://doi.org/10.3390/INFO10110349>

- World Health Organization. (6 de junio de 2022). UN Report: Global hunger numbers rose to as many as 828 million in 2021. <https://www.who.int/news/item/06-07-2022-un-report--global-hunger-numbers-rose-to-as-many-as-828-million-in-2021>
- Westwood, J. H., Charudattan, R., Duke, S. O., Fennimore, S. A., Marrone, P., Slaughter, D. C., Swanton, C., & Zollinger, R. (2018). Weed Management in 2050: Perspectives on the Future of Weed Science. *Weed Science*, 66(3), 275-285. <https://doi.org/10.1017/wsc.2017.78>
- Zhang, J., Yu, F., Zhang, Q., Wang, M., Yu, J., & Tan, Y. (2024). Advancements of UAV and Deep Learning Technologies for Weed Management in Farmland. *Agronomy* 2024, 14(3), 494. <https://doi.org/10.3390/AGRONOMY14030494>